

# PATENT ABSTRACTS OF JAPAN

(11) Publication number : 2003-069924

(43) Date of publication of application : 07.03.2003

(51) Int.Cl.

H04N 5/76

(21) Application number : 2002-230037

(71) Applicant : EASTMAN KODAK CO

(22) Date of filing : 07.08.2002

(72) Inventor : LOUI ALEXANDER C  
GATICA-PEREZ DANIEL

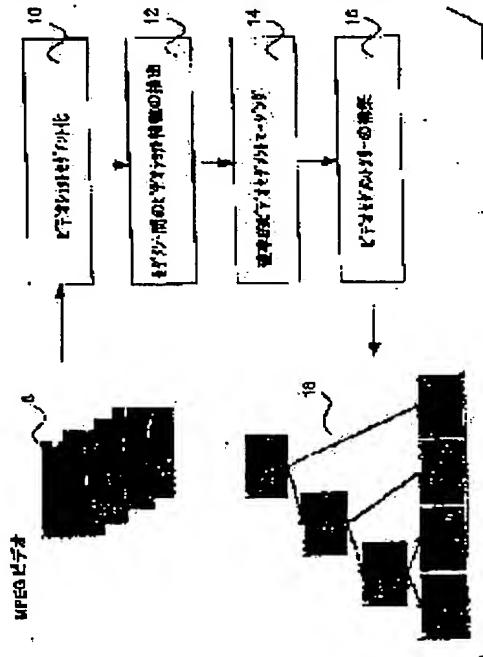
(30) Priority

Priority number : 2001 927041 Priority date : 09.08.2001 Priority country : US

## (54) VIDEO STRUCTURING METHOD BY PROBABILISTIC MERGING OF VIDEO SEGMENT

(57) Abstract:

**PROBLEM TO BE SOLVED:** To generate video clusters without the need for decision of empirical parameters. **SOLUTION:** This invention provides the method for structuring video by probabilistic merging of video segments includes the steps of obtaining a plurality of frames of unstructured video; generating video segments from the unstructured video by detecting short boundaries based on color dissimilarity between consecutive frames; extracting a feature set by processing pairs of segments for visual dissimilarity and their temporal relationship, thereby generating an inter-segment visual dissimilarity feature and an inter-segment temporal relationship feature; and merging video segments with a merging criterion that applies a probabilistic analysis to the feature set, thereby generating a merging sequence representing the video structure. The probabilistic analysis follows a Bayesian formulation and the merging processing is represented in a hierarchical tree structure including frames extracted from each segment.



## LEGAL STATUS

[Date of request for examination] 04.08.2005

[Date of sending the examiner's decision of rejection]

[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision of rejection]

[Date of requesting appeal against examiner's decision of rejection]

[Date of extinction of right]

(19) 日本国特許庁 (JP)

## (12) 公開特許公報 (A)

(11) 特許出願公開番号

特開2003-69924

(P2003-69924A)

(43) 公開日 平成15年3月7日 (2003.3.7)

(51) Int.Cl'

H 04 N 5/76

識別記号

F I

H 04 N 5/76

テマコト<sup>®</sup> (参考)

B 5 C 0 5 2

審査請求 未請求 請求項の数3 OL (全 15 頁)

(21) 出願番号 特願2002-230037 (P2002-230037)  
 (22) 出願日 平成14年8月7日 (2002.8.7)  
 (31) 優先権主張番号 927041  
 (32) 優先日 平成13年8月9日 (2001.8.9)  
 (33) 優先権主張国 米国 (US)

(71) 出願人 590000846  
 イーストマン コダック カンパニー  
 アメリカ合衆国、ニューヨーク14650、ロ  
 チエスター、スティート ストリート343  
 (72) 発明者 アレクサンダー シー ルイ  
 アメリカ合衆国 ニューヨーク 14526  
 ベンフィールド セラマー・ドライヴ 8  
 (74) 代理人 100070150  
 弁理士 伊東 忠彦 (外3名)

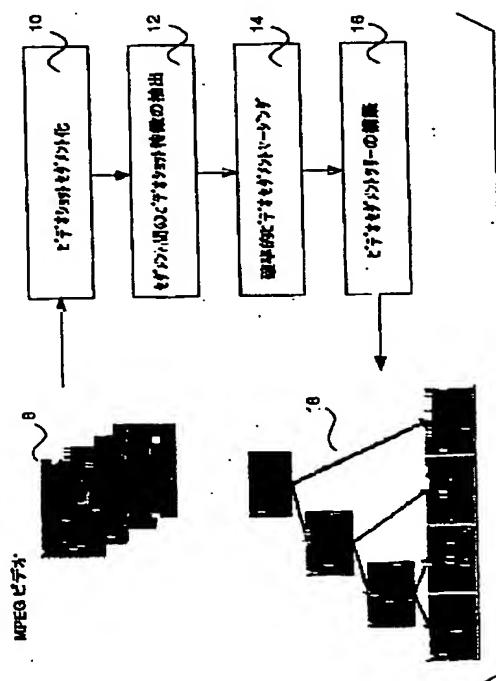
最終頁に続く

(54) 【発明の名称】 ビデオセグメントの確率的マージングによるビデオ構造化方法

(57) 【要約】

【課題】 経験的なパラメータ決定を要せずビデオクラスの生成を可能とすること。

【解決手段】 ビデオセグメントの確率的マージングによりビデオを構造化する方法であって、構造化されていない複数のビデオのフレームを取得するステップと、上記構造化されていないビデオから、連続するフレーム間の色の非類似度に基づきショットの境界を検出することにより、ビデオセグメントを生成するステップと、セグメント間の可視的な非類似度特徴及びセグメント間の時間的関係特徴を生成するため、対のセグメントを処理することにより、可視的な非類似度及びそれらの時間的な関係に対する特徴セットを抽出するステップと、ビデオ構造を表現するマージングシーケンスを生成するため、上記特徴セットに確率的な解析を適用するマージング判断基準によりビデオセグメントをマージングするステップとを含む。確率的解析は、ペイズの定式化に後続し、マージングシーケンスは、各セグメントから抽出されたフレームを含む階層的ツリー構造で表現される。



## (2) 開2003-69924 (P2003-69924A)

## 【特許請求の範囲】

【請求項1】 ビデオセグメントの確率的マージングによりビデオを構造化する方法であって、  
 a) 構造化されていない複数のビデオのフレームを取得するステップと、  
 b) 連続するフレーム間の色の非類似度に基づきショットの境界を検出することによって、上記構造化されていないビデオからビデオセグメントを生成するステップと、  
 c) 対のセグメントを可視的な非類似度及び時間的な関係に対して処理して、セグメント間の可視的な非類似度特徴及びセグメント間の時間的関係特徴を生成することにより、特徴セットを抽出するステップと、  
 d) 上記特徴セットに確率的な解析を適用するマージング判断基準を用いてビデオセグメントをマージングし、ビデオ構造を表現するマージングシーケンスを生成するステップとを含む、方法。

【請求項2】 上記ステップb)は、連続するフレームからカラーヒストグラムを生成するステップと、上記カラーヒストグラムから、連続するフレーム間の色の非類似度を表現する差分信号を生成するステップと、複数のフレームに亘り求めた平均非類似度に基づき上記差分信号を閾値処理し、これにより、ショットの境界の存在を特定する信号を生成するステップとを含む、請求項1記載の方法。

【請求項3】 上記差分信号は、上記連続するフレームの一のフレームを中心としてビデオキャプチャのフレームレートの分数に対応するフレーム数を持つ複数のフレーム、に亘り求めた平均非類似度に基づく、請求項2記載の方法。

## 【発明の詳細な説明】

## 【0001】

【発明の属する技術分野】 本発明は、一般的には、ビデオ素材の処理及び検索に係り、より詳細には、ホームビデオからの情報にアクセスし、組織化し、操作することに関する。

## 【0002】

【従来の技術】 ビデオコンテンツのすべてのソースの中で、構造化されていない消費者のビデオは、おそらく、大部分の人々が現に若しくは最終的に処理することに関心を持ちうるコンテンツを構成している。ホームビデオにアクセスしそれを操作することにより、個人的な記憶を組織化し編集することは、従来の静止画像の組織化の自然な技術的拡張である。しかしながら、かかる取り組みは、デジタルビデオの出現に誘起されるものの、これらの可視的なアーカイブのサイズにより、及び、ホームビデオ情報にアクセスし、組織化し、操作するための効果的なツールの不足により、制限されたままである。かかるツールの作成は、アルバムやビデオベビーブック中のビデオイベントの組織化や、ビデオデータやマルチメ

ディアファミリーウェブページから抽出した静止画によるポストカードの編集等へのドアを開放する。実際には、多種多様なユーザーの興味により対話型の解決策が提案されており、これは、意味のあるレベルで所望のタスクを特定するために最小限のユーザフィードバックを必要とし、また、冗長であるか若しくは高い信頼性で実行できるタスクに対して自動化されたアルゴリズムを付与する。

【0003】 コマーシャルビデオにおいて、多くの動画文書は、可視的なコンテンツに反映されるストーリ構造を有する。かかる場合、完全な動画文書は、ビデオクリップと称される。ビデオの生成の基本単位は、ショットであり、連続的な動作を捕捉する。ビデオショットの特定は、各ショットの開始及び終了を与える風景変化検出スキームによって実現される。風景は、通常的には、位置若しくは印象的な出来事を基にして統合される、少数の相互関係のあるショットからなる。特集フィルムは、典型的には、動画文書のコンテンツを理解するためにストーリラインを定義する、多数の風景からなる。

【0004】 コマーシャルビデオとは対照的に、規制されていないコンテンツ及びストーリラインの不在が、ホームビデオの主なる特性である。消費者コンテンツは、通常には、それぞれが時間軸上でランダムに広がる1若しくは2、3のショットから構成される、関連し若しくは独立したイベントのセットからなる。かかる特性により、消費者ビデオは、ストーリラインモデルに基づくビデオ解析アプローチに対して不適となる。しかし、可視的な類似性、及び、大型のホームビデオデータベースの統計的解析後に明確に表れるビデオセグメント間の時間的近接度 (temporal adjacency) に基づく時空間 (spatio-temporal) 構造が依然として存在する。かかる構造は、消費者の静止画像の構造と実質的に等価であり、ホームビデオの構造化をクラスタリングの問題として対処することを示唆する。当面のタスクは、所与のビデオクリップに存在するクラスタ数の決定、及び、ビデオシーケンス内の各フレーム/ショットにクラスタラベルを割り当てるための最適な基準の設計として定義される。これは、実際に、ストーリラインされたコンテンツを処理するときでさえ、ビデオ解析の大部分の研究で取られる方向性である。

【0005】 例えば、米国特許第5821945号には、検索のための複雑なビデオ選択の階層的な分解を抽出し、ビデオの風景間及び風景内の重要な関係を捕捉するために可視的情報及び時間的情報を結合する技術が開示されている。従って、これは、コンテンツの先見的な知識を用いない潜在的なストーリ構造の解析を可能とする。かかるアプローチは、ビデオショット境界決定 (ショットセグメント化) 及びショットクラスタリングという、2段階の原理体系のバリエーションでビデオ構造化を実現する。第1段階は、これまでビデオ解析で最も研

## (3) 開2003-69924 (P2003-69924A)

究されている（例えば、U.Gargi, R.Kasturi and S.H.S trayer, "Performance Characterization of Video-Shot-Change Detection Method", IEEE CSVT, Vol.10, No. 1, February 2000, p1-13参照）。第2段階に対して、ビデオ構造の基本単位としてショットを用いて、k-means法、分散をベースとしたクラスタリング、及び、時間制約付き（time-constrained）マージング技術のすべてが、先行技術に開示されている。これらの方法の幾つかは、通常的には、アプリケーションに依存するか若しくはユーザフィードバックにより経験的に決定される、多くのパラメータの設定を必要とする。

## 【0006】

【発明が解決しようとする課題】先行技術で理解できるように、階層的な表現は、構造化されていないコンテンツを表現するのに自然であるばかりか、検索及び操作のための有用な非線形対話モデルを付与する最良な方法であるだろう。幸いなことに、副産物として、クラスタリングにより、ビデオコンテンツに対する階層的な表現の生成が可能となる。風景遷移グラフ（例えば、米国特許第5821945号参照）及びツリーに基づくコンテンツのテーブルを含む、階層的な組織化のための異なるモデルは、先行技術において提案されているが、各特定のモデルの効率／有用性は、一般的に、開かれた問題のままである。

【0007】現在に至るまで、幾つかの研究しかホームビデオの解析を取り扱っていない（例えば、G.Iyengar and A.Lippman, "Content-based Browsing and Edition of Unstructured Video", IEEE ICME, New York City, August 2000; R.Lienhart, "Abstracting Home Video Automatically", ACM Multimedia Conference, Orlando, October, 1999, pp.37-41; Y.Rui and T.S.Huang,

"A Unified Framework for Video Browsing and Retrieval", in A.C.Ed., Handbook of Image and Video Processing, Academic Press, 1999参照）。Lienhartの研究は、ビデオサマリーの生成のためのクラスタリングを実行するために時刻記録された（time-stamped）情報を用いる。しかしながら、時刻記録された情報は、常に利用可能ではない。デジタルカメラはこの情報を含んでいるものの、ユーザーは時間オプションを常に使用するとは限らない。それ故に、一般的な解決策は、この情報に依存することができない。Rui及びHuangによる、非常に簡易な統計的仮定に基づくコンテンツのテーブルの生成のための研究は、“ストーリライン”を備えた幾つかのホームビデオで試験を行った。しかしながら、ホームビデオの持つ非常に高いレベルの構造化されていない特性により、特別なストーリラインモデルのアプリケーションが極めて制限される。Iyengar及びLippmanによる記述を除いて、上述のアプローチのいずれも、かかるコンテンツの特有の統計データを詳細に解析していない。この観点から、本発明は、ショット持続時間の統計的モデルに

基づくショット境界検出のためのベイズの法則を提案するN.Vasconcelos及びA.Lippmanによる“A Bayesian Video Modeling Framework for Shot Segmentation and Content Characterization”, Proc.CVPR, 1997の研究、及び、異なる確率法則を用いてホームビデオ解析を取り扱うIyengar及びLippmanによる研究により関連している。【0008】それにも拘らず、先行技術からは、ショットを組織化の基本単位として使用する確率的な原理体系が、対話のためのビデオ階層の生成を支援できるのかが不明である。本発明に至る際、消費者ビデオにおける可視的及び時間的な特徴の統計モデルが組織化のために詳細に調べられた。特に、ベイズの法則は、ホームビデオの時空間構造の事前知識をコード化するのに適するようと思われた。先行技術を出発点として、ここで言及する画期的アプローチは、可視的な類似性、時間的な近接度及び持続時間のセグメント間の特性をジョイントモデルで統合し、経験的なパラメータ決定を用いずにビデオクラスタの生成を可能とする、効果的な確率的ビデオセグメント・マージング・アルゴリズムに基づく。

【0009】本発明は、上述の問題点の一若しくはそれ以上を克服することを目的とする。

## 【0010】

【課題を解決するための手段】簡潔に概説すると、本発明による一局面によれば、ビデオセグメントの確率的マージングによりビデオを構造化する方法であって、

a) 構造化されていない複数のビデオのフレームを取得するステップと、  
b) 上記構造化されていないビデオから、連続するフレーム間の色の非類似度に基づきショットの境界を検出することによりビデオセグメントを生成するステップと、  
c) セグメント間の可視的な非類似度特徴及びセグメント間の時間的関係特徴を生成するため、対のセグメントを処理することにより、それらの可視的な非類似度及び時間的な関係に対する特徴セットを抽出するステップと、

d) ビデオ構造を表現するマージングシーケンスを生成するため、上記特徴セットに確率的な解析を適用するマージング判断基準によりビデオセグメントをマージングするステップとを含む、方法が提供される。好ましい実施例では、確率的解析は、ベイズの定式化に後続し、マージングシーケンスは、各セグメントから抽出されたフレームを含む階層的ツリー構造で表現される。

【0011】上述の如く、本発明は、確率的モデルに基づいて消費者ビデオを構造化する方法を採用する。より具体的には、本発明は、ビデオショットを組織化の基本単位として用いて、ホームビデオ内のクラスタ構造を発見する新規な原理体系を提案する。本原理体系は、2つの概念に基づく。即ち、(i) セグメント間の可視的な類似度、及び、時間的近接度とホームビデオセグメントの持続時間とを含むセグメント間の時間的な関係を表わ

## (4) 開2003-69924 (P2003-69924A)

すための統計モデル（例えば、学習済みジョイント混合ガウスモデル）の改良、及び、(i i) 連続的なバイナリクラス化処理として階層的クラスタリング（マージング）の再定式化である。モデルは、確率的クラスタリングアルゴリズムにて上記(i i)で使用され、これに対して、ペイズの定式化は、これらのモデルがホームビデオの統計的な構造の事前知識を組み込むことができる有用であり、原理化された方法体系の効果を供する。

【0012】ビデオ構造化アルゴリズムは、本発明により効率的に実行可能であり、如何なる特別なパラメータ決定を必要としない。付随的に、ビデオクラスタを見出すことは、ビデオコンテンツに対する階層的な表現の生成を可能とし、検索及び操作のための非線形的なアクセスを提供する。

【0013】本発明の主なる効果は、クラスタ検出及び個々のショットクラスタラベリングに関する本原理体系の性能に基づいて、消費者ホームビデオにおいて見出されるだろう構造化されていないコンテンツを有するビデオ及び構造化されていないビデオを処理することができる。従って、それは、対話的な組織化及びホームビデオ情報の抽出のためのシステム用ツールを確立するための第1ステップである。

【0014】ペイズのビデオセグメントマージングアルゴリズムに基づく消費者ビデオ構造化のための原理体系として、その他の効果は、本方法が、経験的なパラメータ決定を用いることなく、マージング処理を自動的に分配し、また、可視的及び時間的なセグメント非類似度特徴を単一モデルに統合することである。

【0015】更に、ツリーによるマージングシーケンスの表現は、ビデオコンテンツへの階層的な非線形のアクセスを可能とするユーザインターフェースのための基礎を提供する。

【0016】本発明のこれらの及び他の局面、目的、特徴及び効果は、好ましい実施例の次の詳細な説明及び上記特許請求の範囲を精査し、添付図面を参照することにより、より明確に理解できるだろう。

## 【0017】

【発明の実施の形態】ショット検出及びクラスタ解析を用いるビデオ処理システムは公知であるので、本説明は、本発明によるビデオ構造化技術を形成し若しくはより直接的に協働する構成に特に向けられる。ここで具体的に開示されない構成は、本分野で知られている構成から選択されてよい。次の説明では、本発明の好ましい実施例が、通常的にはソフトウェアプログラムとして実行されるだろうが、当業者であればかかるソフトウェアの均等物がハードウェア内に構築されてよいことを容易に理解するだろう。次に開示される本発明によるシステムにおいて、本発明の実現のために有用であるがここで具体的に開示・提案・言及されない素材、ソフトウェアは、従来的であり当業者の通常的な設計事項である。本

発明がコンピュータープログラムとして実現される場合、プログラムは、例えば磁気ディスク（フロッピー（登録商標）ディスクやハードドライブのような）や磁気テープのような磁気記憶媒体、光ディスク、光テープや機械読み取り可能なバーコードのような光記憶媒体、ランダムアクセスメモリ（RAM）やリードオンリーメモリ（ROM）のような固体電子記憶デバイス、コンピュータープログラムを記憶するために用いられる他の物理的デバイスやメディアのような、従来的なコンピューター読み取り可能な記憶媒体に記憶されてよい。

【0018】ホームビデオに記憶された個人的な記憶に対してアクセス、組織化及び操作を行うことは、その構造化されていないコンテンツ及び明確なストーリライン構造の不足に起因して、技術的な課題となる。本発明において、原理体系は、消費者ビデオクリップ中の可視的情報の単位であるショット間の類似度及び近接度の統計的なパラメトリックモデルの発展型に基づく。ショットをマージング（統合）するペイズの法則は、これらのモデルがホームビデオの統計的構造の事前知識をコード化できるので、理にかなった選択に思われる。それ故に、本原理体系は、ショット境界検出及びペイズのセグメントマージングに基づく。セグメント間の可視的な類似度、時間的な近接度、及び、EMアルゴリズムを用いてホームビデオ訓練サンプルから学習されたセグメント持続時間、のガウス混合ジョイントモデルは、観察した特性のクラス条件付き密度を表わすために用いられる。かかるモデルは、バイナリペイズクラス分類器（binary Bayes classifier）を構成するマージングアルゴリズムで使用され、このとき、マージングオーダーは、Highest Confidence First (HCF) の変形により決定され、Maximum a Posteriori (MAP) 判定基準がマージング判定基準を定める。マージングアルゴリズムは、階層的なツリーの使用により効率的に実行され、如何なる経験的なパラメータ決定を必要としない。最終的に、ツリーによるマージングシーケンスの表現がユーザインターフェースのための基礎を付与し、ビデオコンテンツへの階層的で非線形のアクセスを可能とする。

【0019】先ず図1を参照するに、ビデオ構造化方法は、消費者ホームビデオで見出されるような、制約のないコンテンツを典型的に表示する構造化されていないビデオソースから得られる一連のビデオフレーム段階8に對して動作するように示されている。本発明によるビデオ構造化方法の主な特徴は、次の4つの段階で簡潔に要約される（後の段落で詳説する）。

【0020】1) ビデオセグメント化段階10：ショット検出がヒストグラム差分信号の適応的閾値処理（adaptive thresholding）により計算される。1-Dカラーヒストグラムは、各バンドに対して  $N = 64$  量子化レベルにより、RGB空間で計算される。L1メトリックが、2つの連続するフレーム間の非類似度  $d_c(t, t')$

## (5) 開2003-69924 (P2003-69924A)

+1) を表現するために使用される。後処理ステップとして、インプレース・モフォロジック(形態学的な) hit-or-miss 変換(in-place morphological hit-or-miss transform)が、複数の近接ショット境界の存在を無くす対の構造化要素によりバイナリ信号に施される。

【0021】2) ビデオショット特徴抽出段階12: 可視的な類似度が2つの異なるビデオイベントの区別するのに十分でないことは本分野で公知である(Rui及びHuangの記述を参照)。可視的な類似度及び時間的な情報の双方は、先行技術においてショットクラスタリングのために使用されている(しかしながら、かかる変形の統計学的な特性は、ペイズの観点の下で研究されていない)。本発明では、ビデオシーケンスの3つの主なる特徴が、後のマージングに対する判断基準として利用される: 即ち、

- ・可視的な類似度は、セグメント外観を表わす平均セグメントヒストグラムにより表される。平均ヒストグラムは、セグメント内の支配的な色の存在及びそれらの持続性(バーシステンス)の双方を表現する。
- ・セグメント間の時間的な分離は、同一のクラスタへのそれらの帰属の強力な指標である。
- ・2つの個々のセグメントの合計の持続時間も、同一のクラスタへのそれらの帰属に関する強力な指標である(例えば、2つの長いショットは、同一のビデオクラスタに属する可能性が小さい)。

【0022】3) ビデオセグメントマージング段階14: このステップは、ペイズ決定理論に基づく2クラス(マージ/マージなし)パターンクラス分類器を構成することにより実行される。セグメント間の可視的な類似度、時間的な近接度及びEMアルゴリズムを用いてホームビデオ訓練サンプルから学習されたセグメント持続時間のガウス混合ジョイントモデルは、観察した特性のクラス条件付き密度を表わすために用いられる。かかるモデルは、バイナリペイズクラス分類器(binary Bayes classifier)を構成するマージングアルゴリズムで使用され、このとき、マージングオーダは、Highest Confidence First (HCF) の変形により決定され、Maximum a Posteriori (MAP) 判定基準がマージング判定基準を定める。マージングアルゴリズムは、階層的なキューの使用により効率的に実行され、如何なる経験的なパラメータ決定を必要としない。マージング手順のフローチャートは、図2に示され、後に詳説される。

【0023】4) ビデオセグメントツリー構築段階16: マージングシーケンス、即ち、対のビデオセグメントの連続的なマージングを備えたリストは、階層を生成するために記憶及び使用され、そのマージングシーケンスは、バイナリ分割ツリー18により表現される。図5は、典型的なホームビデオからのツリー表現を示す。

【0024】1. 本アプローチの概説

ビデオセグメントに対する特徴ベクトル表現が想定される。即ち、ビデオクリップがショット若しくはセグメント(セグメントは、1以上のショットからなる)に分割されており、それらを表現する特徴が抽出されていることを想定する。如何なるクラスタリング手順であっても、ホームビデオクリップ内の各セグメントにクラスタラベルを割り当てると共にクラスタ数(クラスタは一若しくはそれ以上のセグメントを包囲してよい)を決定するためのメカニズムを規定すべきである。クラスタリング処理は、ビデオイベントが限られた持続時間であるので(Rui及びHuangの記述を参照)、時間を制約として含む必要がある。しかしながら、ホームビデオのセグメント間の特徴に対する一般的な発生モデルの定義は、それらの構造化されていないコンテンツに起因して、特に困難である。代わりに、本発明によれば、ホームビデオは、統計的セグメント間モデルを用いて解析される。換言すると、本発明は、対のセグメントに定義された可視的及び時間的特徴の特性を表わすモデルを構築することを提案する。セグメント間の特徴は、必然的にマージングフレームワークに出現し、可視的な非類似度、持続時間及び時間的な近接度を統合する。マージングアルゴリズムは、対のビデオセグメントを連続的に取得し、それらがマージされるべきか否かを決定する、クラス分類器とみなすことができる。 $s_i$  及び  $s_j$  を、ビデオクリップ内の  $i$  番目のビデオセグメント及び  $j$  番目のビデオセグメントとし、 $\epsilon$  を、かかる対のセグメントが同一のクラスタに対応するか否か及びマージされるべきか否かを指示する、バイナリランダム変数( $r, v.$ )とする。マージング処理の構成は、連続的な2クラス(マージ/マージなし)パターンクラス化問題として、ペイズ決定理論からの概念の適用を可能とする(ペイズ決定理論の詳細については、例えばR.O.Duda, P.E.Hart and D.G.S tork, Pattern Classification, 2th ed., John Wiley and Sons, 2000を参照)。Maximum a Posteriori (MAP) 判定基準は、 $r, v, x$ (セグメント間の特徴を表わし、後に詳説される。)のn次元の実現  $x_{i,j}$  を仮定して、選択されなければならないクラスが、 $x$ の下での $\epsilon$ の事後確率質量関数を最大にするクラスであることを確立する。即ち、

【0025】

【数1】

$$\epsilon^* = \arg \max \Pr(\epsilon | x)$$

ペイズの法則により、

【0026】

【数2】

$$\Pr(\epsilon | x) = \frac{p(x | \epsilon) \Pr(\epsilon)}{p(x)}$$

ここで、 $p(x | \epsilon)$  は  $\epsilon$  の下での  $x$  の尤度であり、 $P$

(6) 開2003-69924 (P2003-69924A)

$r(\varepsilon)$  は、 $\varepsilon$ の事前確率 (prior) であり、 $P(x)$  は、特徴の分散である。MAP原理の適用は、次のように表現でき、

$$\varepsilon^* = \begin{cases} 1, & p(x | \varepsilon = 1) \Pr(\varepsilon = 1) > p(x | \varepsilon = 0) \Pr(\varepsilon = 0) \\ 0, & \text{otherwise} \end{cases}$$

若しくは、標準的な仮説試験表記法では、MAP原理は、次のように表現できる。即ち、

【0028】

【数4】

$$\frac{H_1}{H_0} = \frac{p(x | \varepsilon = 1) \Pr(\varepsilon = 1)}{p(x | \varepsilon = 0) \Pr(\varepsilon = 0)}$$

ここで、 $H_1$  は、対のセグメントがマージされるべきであるとする仮説を指示し、 $H_0$  は、その逆を指示する。この公式を用いると、対のショットのクラス化は、所定の終了条件が満たされるまで連続的に実行される。それ故に、タスクは、有用な特徴空間の決定、分散に対するモデルの選択及びマージングアルゴリズムの規定である。これらのステップのそれぞれは、次に段落に言及される。

【0029】2. ビデオセグメント化

基本のセグメントを生成するため、ショット境界検出が、段階10で、ホームビデオに通常に見出される切れ目 (カット) を検出するための一連の方法により計算される (例えば、U. Gargi, R. Kasturi and S. H. Straye, "Performance Characterization of Video-Shot-Change Detection Method", IEEE CSVT, Vol. 10, No. 1, February 2000, p1-13参照)。検出エラーに起因した過剰なセグメント化は、クラスタリングアルゴリズムにより対処できる。更に、中身のほとんどないビデオは除去される。

【0030】本発明の好ましい実施例において、ショット検出は、ヒストグラム差分信号の適応的閾値処理により決定される。1-D (一次元) カラーヒストグラムは、各バンドに対して  $N = 64$  量子化レベルにより、RGB空間で計算される。他のカラー モデル (LAB や LUV) も使用可能であり、より良好なショット検出を付与しうるが、計算負荷が増加する。L1 メトリックが、2つの連続するフレーム間の非類似度  $d_c(t, t+1)$  を表現するために使用される。即ち、

【0031】

【数5】

$$d_c(t, t+1) = \sum_{k=1}^{3N} |h_t^k - h_{t+1}^k|$$

ここで、 $h_t^k$  は、フレーム  $t$  の連結RGBヒストグラムに対する  $k$  番目のビンの値を示す。次いで、一次元信号  $d_c$  は、 $f_r$  をフレームレートとしたとき、長さ  $f_r$

【0027】

【数3】

／2の時間  $t$  で中心化したスライディング・ウインドウ (sliding window) により計算される閾値により二値化される。即ち、

【0032】

【数6】

$$s(t) = \begin{cases} 1, & d_c(t) > \mu_d(t) + k\sigma_d(t) \\ 0, & \text{otherwise} \end{cases}$$

ここで、 $\mu_d(t)$  は、スライディング・ウインドウにより計算される非類似度の平均であり、 $\sigma_d(t)$  は、その平均値周辺のデータセットの変動のよりロバストな推定量であることが知られている、ウインドウ内の非類似度の平均絶対偏差を示し、 $k$  は、閾値の決定のための信頼区間を設定する係数であり、閾値は、当該区間に設定される。連続したフレームは、それ故に、 $s(t) = 0$  の場合には同一のショットに属すると考えられ、隣接するフレーム間のショット境界は  $s(t) = 1$  のときに特定される。

【0033】後処理ステップとして、インプレース・モフォロジック (形態学的な) hit-or-miss 変換 (in-place morphological hit-or-miss transform) が、複数の近接ショット境界の存在を無くす対の構造化要素によりバイナリ信号に適用される。即ち、

【0034】

【数7】

$$b(t) = s(t) \otimes (e_1(t), e_2(t))$$

ここで、

【0035】

【外1】

⊗

は、hit-or-miss を示し、構造化要素のサイズは、ホームビデオショット持続時間ヒストグラム (ホームビデオショットは、2秒より短く持続しないだろう) に基づき、 $f_r/2$  に設定される (Jean Serra: Image Analysis and Mathematical Morphology, Vol. 1, Academic Press, 1982 参照)。

【0036】3. ビデオセグメント間の特徴決定

可視的な非類似度、時間的分離度及び積算したセグメント持続時間に対する特徴セットは、ビデオショット特徴抽出段階12で生成される。可視的な非類似度及び時間的情報の双方、特に時間的分離度は、過去にクラスタリングのために使用されている。可視的な非類似度の場合、可視的特徴の違いの分かる出力の観点で、単一のフ

(7) 開2003-69924 (P2003-69924A)

レームが、セグメントのコンテンツを表現するのに十分でない場合があることは明らかである。幾つかの利用可能な解決法から、平均セグメントカラーヒストグラムが、セグメント外観を表現するために選択される。即ち、

【0037】

【数8】

$$m_i = \frac{1}{M_i} \sum_{t=1}^T h_t$$

ここで、 $h_t$  は、 $t$  番目のカラーヒストグラムを示し、 $m_i$  は、それぞれ  $M_i = e_i - b_i + 1$  のフレーム ( $e_i$  及び  $b_i$  は、セグメント  $s_i$  の開始及び終了フレームを示す) からなるセグメント  $s_i$  の平均ヒストグラムを示す。平均ヒストグラムは、セグメント内の支配的な色の存在及びそれらの持続性を表現する。平均セグメントヒストグラム差の L1 ノルムが対のセグメント  $i, j$  を実質的に比較するために用いられる。即ち、

【0038】

【数9】

$$\alpha_{ij} = \sum_{k=1}^K |m_{ik} - m_{jk}|$$

ここで、 $\alpha_{ij}$  は、セグメント  $i, j$  間の可視的非類似度を示し、 $B$  はヒストグラム bin の数を示し、 $m_{ik}$  は、セグメント  $s_i$  の平均カラーヒストグラムの  $k$  番目の bin の値であり、 $m_{jk}$  は、セグメント  $s_j$  の平均カラーヒストグラムの  $k$  番目の bin の値である。

【0039】時間的情報の場合、同一のクラスタへのそれらの帰属についての強力な指標である、 $s_i$  と  $s_j$  との間の時間的分離度は、次の通り定められる。即ち、

【0040】

【数10】

$$\beta_{ij} = \min(|e_i - b_j|, |e_j - b_i|) / (1 - \delta_{ij})$$

ここで、 $\delta_{ij}$  は、クロネッカーのデルタを示し、 $b_i, e_i$  は、セグメント  $s_i$  の最初と最後のフレームを示し、 $b_j, e_j$  は、セグメント  $s_j$  の最初と最後のフレームを示す。

【0041】更に、2つの別個のセグメントの積算セグメント（合計の）継続時間は、同一のクラスタへのそれらの帰属についての強力な指標である。図3は、グラウンドトルースによるデータベースからの約660個のショットに対する経験的なホームビデオショット持続時間を見し、その適合はガウス混合モデル（次の段落を参照）による。（図3には、経験的な持続時間、及び、6つの構成要素からなる推定されたガウス混合モデルが重ね合わせられている。持続時間は、最も長い持続時間（580秒）で正規化されている。）ビデオが異なるシナリオに対応し、複数の人によって撮影されているにも拘らず、明らかな時間的パターンが存在する（Vasconcelos 及び Lippman の記述参照）。積算したセグメント持続

時間  $\tau_{ij}$  は、次の通り定義される。即ち、

【0042】

【数11】

$$\tau_{ij} = \text{card}(s_i) + \text{card}(s_j)$$

ここで、 $\text{card}(s)$  は、セグメント  $s$  中のフレーム数を示す。

【0043】4. 尤度及び事前確率のモデリング

セグメント間の特徴セットの統計的モデリングは、ビデオセグメントマージング段階 1.4 で生成される。上述の3つの特徴は、ベクトル  $x = (\alpha, \beta, \tau)$  により、特徴空間  $X$  の成分となる。2つのクラスの分離度を解析するため、図4は、ホームビデオから抽出された4000個のラベル標示されたセグメント間特徴ベクトルの散在するプロットを示す。（サンプルの半分は、仮説  $H_1$  に対応し（セグメントペアが共に帰属し、薄い灰色でラベル標示）、他の半分は、仮説  $H_0$  に対応する（セグメントペアは、共に帰属せず、濃い灰色でラベル標示）。特徴は正規化されている。）

プロットは、2つのクラスが一般的に分離されていることを示す。このプロットの投影図は、純粹な可視的類似度に依存することの限界を明示する。パラメトリック混合モデルは、観察したセグメント間の各特徴クラス条件付き密度に対して適合される。即ち、

【0044】

【数12】

$$p(x | \varepsilon, \Theta) = \sum_i^K \Pr(c=i) p(x | \varepsilon, \theta_i)$$

ここで、 $K_\varepsilon$  は、各混合中の成分数を示し、 $\Pr(c=i)$  は、 $i$  番目の成分の事前確率を示し、 $p(x | \varepsilon, \theta_i)$  は、 $\theta_i$  によりパラメータ表示される  $i$  番目の  $p$  df であり、すべてのパラメータのセットを表わす。本発明において、 $d$  次元の混合の成分に対して下式の多変量ガウス形が想定され、

【0045】

【数13】

$$p(x | \varepsilon, \theta_i) = \frac{1}{(2\pi)^{d/2} |\Sigma_i|^{1/2}} e^{-\frac{1}{2} (x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i)}$$

パラメータ  $\theta_i$  は、平均  $\mu_i$  及び共分散行列（covariance matrices） $\Sigma_i$  である（Duda他、Pattern Classification, op. cit. 参照）。

【0046】公知のEMアルゴリズムは、パラメータ  $\Theta$  のセットの最尤（ML）推定法に対する標準の手順を構成する（A.P. Dempster, N.M. Laird and D.B. Rubin, "Maximum Likelihood from Incomplete Data via the EM Algorithm", Journal of the Royal Statistical Society, Series B, 39:1-38, 1977 参照）。EMは、観察データがある意味で不完全である場合に、問題の広い範囲に対するML推定値を見出すための知られた技術である。ガウス混合の場合、不完全データは、観察されない

(8) 開2003-69924 (P2003-69924A)

混合成分であり、その事前確率はパラメータ {Pr (c)} である。EMは、反復的なヒルクライミング (hill-climbing) 手順を用いることによる、観察データの下での完全データの対数尤度の条件付き期待値を増大することに基づく。更に、モデル選択、即ち各混合の成分数は、最大記述長 (MDL) 原理を用いて自動的に推定できる (J.Rissanen, "Modeling by Shortest Data Description", Automatica, 14:465-471, 1978)。

【0047】一般的なEMアルゴリズムは、任意の分散に対して有効であり、観察データ  $X = \{x_1, \dots, x_n\}$  の下での完全データ  $Y$  の対数尤度の条件付き期待値を増大することに基づく。即ち、

【0048】

【数14】

$$Q(\theta | \theta^{(p)}) = E\{\log p(Y | \theta) | x, \theta^{(p)}\}$$

であり、反復的なヒルクライミング手順を用いることによる。前式において、 $X = h(Y)$  は、既知の多対一関数 (many-to-one function) (例えば、部分集合演算子) を表わし、 $x$  はデータのシーケンス若しくはベクトルを表わし、 $p$  は反復数を示す上付き文字である。EMアルゴリズムは、最大の  $Q(\theta)$  に収束するまで、次の2つのステップを繰り返す。即ち、

E-STEP: 完全データの所期の尤度を  $\theta$ 、 $Q(\theta | \theta^{(p)})$  の関数として導出する。

M-STEP: 次式により、パラメータを再推定する。

【0049】

【数15】

$$\pi_i^{(p+1)} = \frac{1}{N} \sum_{j=1}^N p(i | x_j, \varepsilon, \theta^{(p)})$$

$$\mu_i^{(p+1)} = \frac{\sum_{j=1}^N x_j p(i | x_j, \varepsilon, \theta^{(p)})}{\sum_{j=1}^N p(i | x_j, \varepsilon, \theta^{(p)})}$$

$$\Sigma_i^{(p+1)} = \frac{\sum_{j=1}^N p(i | x_j, \varepsilon, \theta^{(p)}) (x_j - \mu_i^{(p+1)}) (x_j - \mu_i^{(p+1)})^T}{\sum_{j=1}^N p(i | x_j, \varepsilon, \theta^{(p)})}$$

混合成分のそれぞれに対する平均ベクトル及び共分散行列は、最初に初期化されなければならない。本実施例では、平均値は、従来的な  $K$ -means アルゴリズムを用いて初期化されるが、共分散行列は、恒等行列を用いて初期化される。他のヒルクライミング法として、データ駆動型初期化は、通常的には、純粹なランダム初期化

$$\theta^{(p+1)} = \arg \max_{\theta} Q(\theta | \theta^{(p)})$$

換言すると、第1にE-STEPで不完全データを埋める値を推定する (対数尤度自体に代わって、観察データの下での完全データの対数尤度の条件付き期待値を用いる)。次いで、M-STEPで用いる最大尤度パラメータ推定値を計算し、適切な終了基準に達するまで反復される。EMは、サンプルセットの尤度の局所最大値に収束する反復アルゴリズムである。

【0050】多変量ガウスモデルの特別の場合に対して、完全データは  $Y = (X, I)$  により与えられ、ここで、 $I$  は観察データの各サンプルを生成する際に使用されたガウス成分を示す。要素に関しては、 $y = (x, i)$ 、 $i = \{1_1, \dots, K_e\}$  である。かかる場合、EMは、更に簡略化された形となる。即ち、

E-STEP: すべての  $N$  個の訓練用サンプル及びすべての混合成分に対して、ガウス  $i$  が現在の推定の下でサンプル  $x_j$  に適合する確率を計算する。

【0051】

【数16】

$$p(i | x_j, \varepsilon, \theta^{(p)}) = \frac{\pi_i p(x_j | \varepsilon, \theta_i^{(p)})}{\sum_{k=1}^K \pi_k p(x_j | \varepsilon, \theta_k^{(p)})}$$

M-STEP: パラメータを再推定する。

【0052】

【数17】

よりも良好に実現する。更に、EM反復の連続的な再始動時、少量のノイズが各平均値に加えられ、局所最大にトラップさせるための手順を漸減する。

【0053】収束判定基準は、連続的な反復での観察データの対数尤度の増加率により規定される。

【0054】

(9) 開2003-69924 (P2003-69924A)

【数18】

$$\log L(\Theta | X) = \log \prod_{j=1}^N P(x_j | \varepsilon, \Theta)$$

即ち、EM反復は、

【0055】

【数19】

$$\frac{\log L(\Theta^{(p+1)} | X) - \log L(\Theta^{(p)} | X)}{\log L(\Theta^{(p)} | X)} \leq 10^{-2}$$

のときに終了する。

【0056】特別なモデル、即ち各混合の成分の数  $K_\varepsilon$  は、最大記述長 (MDL) 原理を用いて、

【0057】

【数20】

$$K_\varepsilon^* = \arg \max_{K_\varepsilon} (\log L(\Theta | X) - \frac{n_{K_\varepsilon}}{2} \log N)$$

を選択することにより、自動的に推定される。ここで、 $L(\cdot)$  は訓練用セットの尤度を示し、 $n_{K_\varepsilon}$  は、モデルに必要なパラメータ数であり、ガウス混合に対しては、

【0058】

【数21】

$$n_{K_\varepsilon} = (K_\varepsilon - 1) + K_\varepsilon d + K_\varepsilon \frac{d(d+1)}{2}$$

となる。2つのモデルが同様な方法でサンプルに適合するとき、より簡略化したモデル（より小さい  $K_\varepsilon$ ）が選択される。【0059】変数の間で独立想定を課すことに代わって、完全なジョイントクラス条件付  $p_{\text{dfs}}$  が推定される。 $p(x | \varepsilon=0)$  及び  $p(x | \varepsilon=1)$  に対するパラメトリックモデルのML推定は、上述の手順によって、それぞれの場合で10個の成分により表現される確率密度を生成する。【0060】ベイズのアプローチでは、事前確率質量関数  $P_r(\varepsilon)$  は、特別な問題に関する目下の事前知識のすべてをコード化する。この特別な場合、これは、マージング処理特性についての知識若しくは確信を表わす（ホームビデオクラスタは、たいてい2,3個のショットのみからなる）。探究可能な多種多様な解決法が存在する。-最も単純な想定は、 $P_r(\varepsilon=0) = P_r(\varepsilon=1) = 1/2$  であり、MAP判定基準をML判定基準に変える。

-事前確率自体は、訓練用データからML推定できる (Duda他による Pattern Classification, op.cit. 参照)。Nが独立であると想定し、事前確率のML推定量が、

【0061】

【数22】

$$Pr(\varepsilon = e) = \frac{1}{N} \sum_{k=1}^N i(e, k)$$

であることを示すことは明瞭である。ここで、

【0062】

【外2】

$$i(e, k)$$

は、k番目の訓練用サンプルが、 $\varepsilon = e$ ,  $e \in \{0, 1\}$  により表現されるクラスに属する場合には1であり、それ以外の場合には0である。他言すると、事前確率は、利用可能な根拠（訓練データ）により決定される単なる重みである。

-マージングアルゴリズムに伴うダイナミックス（次の段落で示される）もまた、連続的な態様で事前知識に影響を及ぼす（より多くのセグメントが処理の終了時よりも開始時にマージされるだろうことが予測されている）。他言すると、事前確率は、この基本原理に基づいて動的に更新できる。

【0063】5. ビデオセグメントクラスタリング  
マージングアルゴリズムは、ビデオセグメントマージング段階1-4で実行される。如何なるマージングアルゴリズムも3つの要素を必要とする。即ち、特徴モデル、マージングオーダー、及びマージング判定基準である (L. Garrido, P. Salembier, D. Garcia, "Extensive Operators in Partition Lattices for ImageSequence Analysis", Sign. Proc., 66(2): 157-180, 1998)。マージングオーダーは、どのクラスタが処理の各ステップで可能なマージングのための探査されるべきかを決定する。マージング判定基準は、マージングの可否の判断を行う。各クラスタの特徴モデルは、マージングが発生した場合には更新されるべきである。本ビデオセグメントクラスタリング法は、前の段落での改良型の統計的セグメント間モデルに基づいて、この一般的な定式化を利用する。本アルゴリズムにおいて、クラス条件が、マージング判定基準及びマージングオーダーの双方を定めるために用いられる。

【0064】マージングアルゴリズムは、近接度グラフ及び階層的キューを用いて効率的に実行でき、優先順位付けした処理を可能とする。処理されるべき要素は、優先度を割り当てられ、それに従ってキューに案内される。このとき、各ステップで抽出された要素は、最も高い優先度を持つ要素である。階層的キューは、今日では、数学的形態学における従来的なツールである。その使用は、C. Chou及びC. Brownによる "The Theory and Practice of Bayesian Image Labeling", IJCV, 4, pp. 185-210, 1990にて、Highest Confidence First (HCF) 最適化法による、ベイズの画像解析で初めて開示される。その概念は、直感的なアピーリングである。即ち、決定



(11) 2003-69924 (P2003-69924A)

56) に収束する完全なマージングシーケンスが確立される。全体のビデオクリップは、それ故に、階層の第3レベルを構成する。マージングシーケンスは、次いで、可視的なコンテンツの階層的な表現のための効果的な構造であると知られている、バイナリ分割ツリー(BPT)により表現される。BPTでは、各ノード(リーフを除いて、初期のショットに対応する)は、2つの子を有する。(P.Salembier, L.Grido, "Binary Partition Tree as an Efficient Representation for Filtering, Segmentation, and Information Retrieval", IEEE Intl. Conference on Image Processing, ICIP '98, Chicago, Illinois, October 4-7, 1998) また、BPTは、ユーザ対話のためのツールを確立するための開始点を提供する。

【0077】ツリー表現は、自動的に生成されたビデオクラスタの可視化及び操作(検証、訂正、像拡大、再組織化)のための使いやすいインターフェースを提供する。ホームビデオコンテンツの一般性及び多様なユーザの好みの下で、人手によるフィードバック機構は、ビデオクラスタの生成を改善し、更にユーザのビデオに何かを実際に施しうる可能性をユーザに与えるだろう。

【0078】マージング処理のツリー表現50を表示するための単純なインターフェースでは、実行プログラムは、マージングシーケンスを読み出し、各セグメントから抽出されたフレームによりシーケンスの各ノードを表現する、バイナリツリーを確立するだろう。ランダムフレームは、ツリーの各リーフ(ショット)を表現する。各親ノードは、より少ないショット数の子のランダムフレームにより表現される。(用語"ランダム"は、"キーフレーム"を選ぶ際に一切の作業を要しないので、

"キーフレーム"に代わって好ましいことに注意されたい。)注記するに、図5に示す表現は、また、マージング処理を可視化し、多数のクラスタを特定するのに有用であり、若しくは、ショット数が少ないとの一般的な表示のために有用であるが、それは、元のショット数が大きいときに非常に深くなることができる。

【0079】インターフェースの第2バージョンは、階層の3つのレベルのみ: 即ち、ツリーのリーフ、確率的マージングアルゴリズムの結果として得られるクラスタ、及び完全ビデオのノードのみを表示しうる。操作のモードは、マージングシーケンスの対話的な再組織化を可能とすべきであり、ユーザが自由にクラスタ間でのビデオセグメントの交換や、複数のビデオクリップからのクラスタの結合等をできるようにする。ツリーノードをクリックしたときのプレビューシーケンスの再生及びV

CR能力のような、他の所望の機能を備えたインターフェースの統合は、当業者にとって明らかである。

【0080】本発明は、好ましい実施例を参照して言及されてきた。しかしながら、変形及び修正が当業者により本発明の観点から逸脱することなくなされうることを理解すべきである。本発明の好ましい実施例は、消費者ホームビデオを例に言及されているが、本発明は、デジタル映画の要約及びストーリーボード化、ニュース及び製品関連のインタビューからのビデオ資材の組織化、動きが伴うヘルスイメージングアプリケーション等を含むがこれに限定されない、他のアプリケーションに容易に適用可能であることを理解すべきである。

#### 【図面の簡単な説明】

【図1】本発明によるビデオ構造化の基本的な概要を示すブロック図である。

【図2】図1に示すビデオセグメントマージング段階のフローチャートである。

【図3】消費者画像の集合に対する消費者ビデオショット持続時間の分散プロット図である。

【図4】ホームビデオから抽出されたラベル付きのセグメント間特徴ベクトルの点在プロット図である。

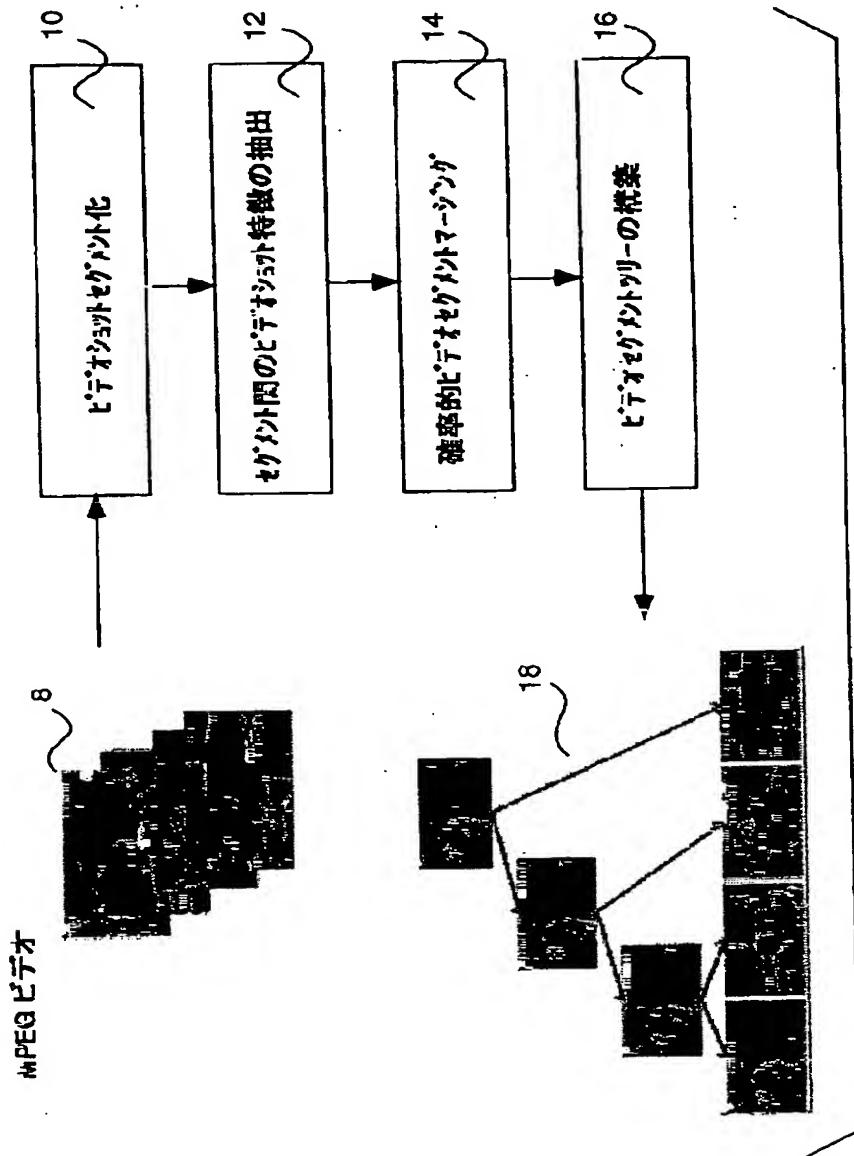
【図5】典型的なホームビデオからのキーフレームのツリー表現を示す図である。

#### 【符号の説明】

8	ビデオフレーム
10	ビデオセグメント段階
12	ビデオショット特徴抽出段階
14	ビデオセグメントマージング段階
16	ビデオセグメントツリー構築
18	バイナリ分割ツリー
20	キー初期化段階
22	処理の開始
30	キー枯渇/更新段階
32	キーの空を判断
34	要素抽出段階
36	MAP判定基準適用
38	$H_1$ に対する経路
40	セグメントモデル更新段階
42	キー更新段階
44	$H_2$ に対する経路
50	ツリー表現
52	第1レベル
54	第2レベル
56	全体のビデオクリップ

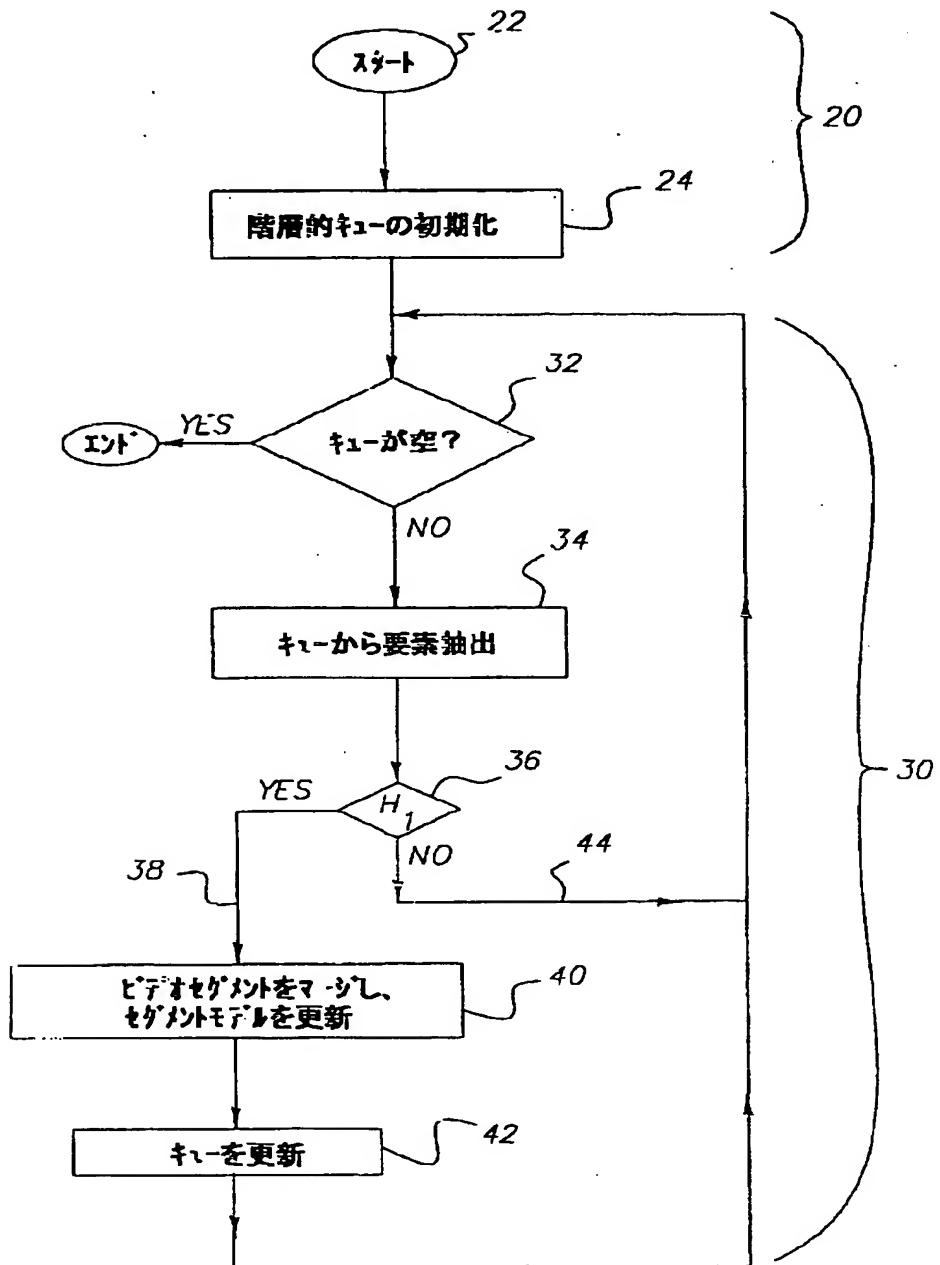
(12) 2003-69924 (P2003-69924A)

【図1】



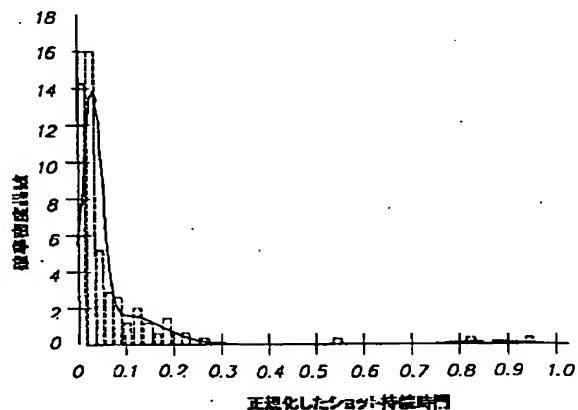
(13) 2003-69924 (P2003-69924A)

【図2】

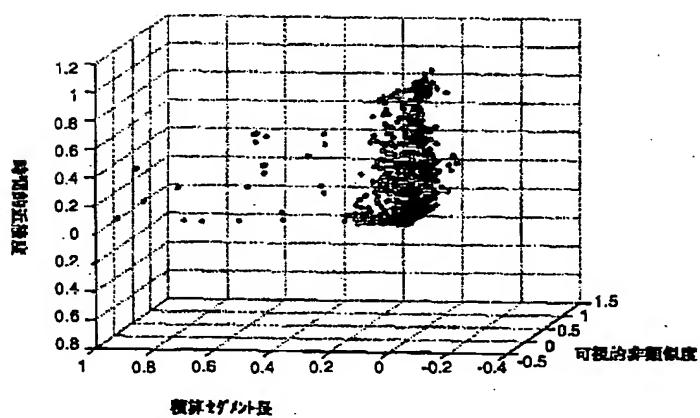


(14) 2003-69924 (P2003-69924A)

【図3】

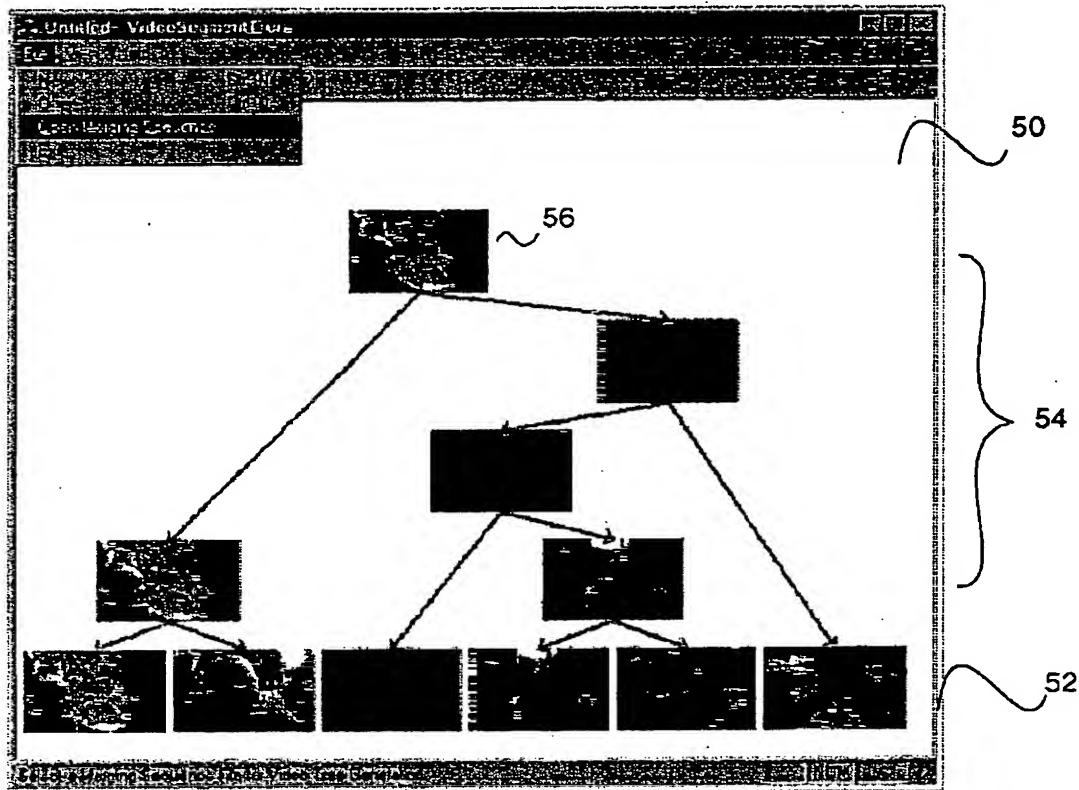


【図4】



(15) 2003-69924 (P2003-69924A)

【図5】



フロントページの続き

(72)発明者 ダニエル ガティカーペレス  
アメリカ合衆国 ワシントン 98115 シ  
アトル サーティース・アヴェニュー・ノ  
ースイースト 6053

Fターム(参考) 5C052 AB02 AC08 DD04 EE03